



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

SEGMENTACE CÉVNÍHO ŘEČIŠTĚ NA SNÍMCÍCH SÍTNICE POMOCÍ KLASIFIKAČNÍCH TECHNIK

BLOOD VESSEL SEGMENTATION IN FUNDUS IMAGES USING CLASSIFICATION METHODS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

PAVEL ŠŤASTNÝ

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. JAN ODSTRČILÍK

BRNO 2013



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Bakalářská práce

bakalářský studijní obor

Biomedicínská technika a bioinformatika

Student: Pavel Šťastný

ID: 133987

Ročník: 3

Akademický rok: 2012/2013

NÁZEV TÉMATU:

Segmentace cévního řečiště na snímcích sítnice pomocí klasifikačních technik

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s principem snímání očního pozadí pomocí fundus kamery a s vlastnostmi takto získaných obrazových dat. Přednostně se zaměřte na charakteristické vlastnosti cévního řečiště. 2) Proveďte rešerši dostupné literatury z oblasti segmentace cévních struktur na snímcích sítnice a zaměřte se zejména na metody využívající klasifikační přístupy. 3) Dle pokynů vedoucího vybraný přístup implementujte v libovolném programovém prostředí. 4) Vytvořenou metodu otestujte na dostupných obrazových datech a vyhodnoťte její účinnost. 5) Proveďte diskusi výsledků a zhodnoťte využitelnost aplikovaného řešení. 6) K vytvořeným programovým funkcím sepište přehledný návod k obsluze.

DOPORUČENÁ LITERATURA:

[1] ODSTRČILÍK J., et al. Improvement of Vessel Segmentation by Matched Filtering in Colour Retinal Images. IFMBE Proceedings, vol. 25, pp. 327-330, 2009.

[2] LUPASCU, A. C., et al. FABC: Retinal vessel segmentation using AdaBoost. IEEE Trans. on Inf. Technol. in Biomed., vol. 14, no.5, pp. 1267-1274, Sep. 2010.

Termín zadání: 11.2.2013

Termín odevzdání: 31.5.2013

Vedoucí práce: Ing. Jan Odstrčilík

Konzultanti bakalářské práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Segmentace cévního řečiště na snímcích sítnice je velmi důležitá pro hodnocení a diagnostiku očních onemocnění, převážně diabetické retinopatie a glaukomu. Tato práce se zabývá segmentací cévního řečiště pomocí klasifikačních metod. Pro kvalifikaci bylo použito jednoduché neuronové sítě. Nejdříve byla učena, pomocí delta pravidla, a poté byla aplikována na předem připravený snímek přizpůsobenou filtrací. Po klasifikaci byl snímek ještě upraven a prahován. Nakonec bylo vše porovnáno se zlatým standardem. Průměrné hodnoty z hodnocení pro zdravé snímky byly senzitivita 0,7717, specifická 0,9571 a přesnost hodnocení 0,9225.

Klíčová slova fundus kamera, snímky sítnice, segmentace cév, metody segmentace cévního řečiště, neuronové sítě, přizpůsobená filtrace

Abstract

Segmentation blood vessel the local images of retinal is very important for evaluation and for diagnostics eye's disease, especially diabetic retinopathy and glaucoma. This bachelor's thesis is deal with segmentation blood vessel by classification methods. I used simple neural network as a classifier. First of all I taught her by delta rule and then I used matched filtering on the prepare image. At the end I compared all information with gold standard. Average values from score for healthy images were sensitivity 0,7717, specificity 0,9571 and accuracy score 0,9225.

Keywords fundus camera, retinal images, blood vessels segmentation, methods of automatic vessel segmentation, neural networks, matched filter

ŠŤASTNÝ, P. *Segmentace cévního řečiště na snímcích sítnice pomocí klasifikačních technik*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2013. 42 s. Vedoucí bakalářské práce Ing. Jan Odstrčilík.

Prohlášení

Prohlašuji, že svou bakalářskou práci na téma Segmentace cévního řečiště na snímcích sítnice pomocí klasifikačních technik jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením tohoto projektu jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestně-právních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009Sb.

V Brně dne 30. 5. 2013

.....
podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce Ing. Janu Odstrčilíkovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně dne 30. 5. 2013

.....
podpis autora

Obsah

Úvod	1
1. Obrazová data z fundus kamery Canon	3
CF- 60 UVi	3
1.1. Fundus kamera	3
1.2. Parametry fundus kamery Canon CF- 60 UVi.....	4
Vlastnosti.....	4
Technické specifikace	5
1.3. Vlastnosti barevných snímků z fundus kamery	5
1.4. Cévní struktury na snímcích sítnice	6
2. Databáze obrazů z fundus kamery pro segmentaci cévního řečiště	8
2.1. Projekt STARE.....	8
2.2. Databáze DRIVE.....	9
2.3. Databáze HRF	10
3. Známé způsoby řešení problematiky segmentace cévního řečiště	12
3.1. Sledování	12
3.2. Pomocí neuronových sítí	12
3.3. Filtrací.....	13
4. Návrh metody segmentace s využitím perceptronu.....	15
4.1. Teorie umělých neuronů a neuronových sítí.....	15
Vlastnosti.....	15
Využití neuronových sítí	16
4.2. Popis neuronu použitého v této práci	16
4.3. Učení s učitelem	16
Algoritmus učení	17
Algoritmus vybavování.....	17
4.4. Prahování	18
4.5. Implementování aplikace	19
5. Diskuze a zhodnocení výsledků	20
5.1. Kritéria k hodnocení	20
Sensitivita	20
Specificita.....	20

Accuracy – přesnost měření	20
5.2. Výsledky testování a zhodnocení metody	22
Snímky zdravých pacientů	22
Snímky pacientů s diabetickou retinopatií	24
Snímky pacientů postižených glaukomem	26
6. Návod k aplikaci	28
Funkce uceniNN.m	28
Funkce vybavovaniNN_a_prahovani.m	28
Funkce hodnoceni.m	29
7. Závěr	30
Použitá literatura	31
8. Použité zkratky	33

Seznam obrázků

Obr. 1.1: Fundus kamera Canon CF - 60 UVi převzato z [18].....	3
Obr. 1.2: Konstrukční schéma fundus kamery: 1 - zobrazovací jednotka; 2, 3, 4 - poziční jednotka; 5 - operační panel pro lékaře; 6 - objektiv, 7 – PC, převzato z [1].....	4
Obr. 1.3: Snímek zadní části sítnice z databáze HRF.....	6
Obr. 1.4: Zobrazení ve třech kanálech: a) červený kanál, b) zelený kanál, c) modrý kanál.....	6
Obr. 1.5: Struktura cévního řečiště na sítnici, v zeleném kanálu.	7
Obr. 1.6: Detail cév, můžeme zde vidět tepny, žíly a centrální reflex.	7
Obr. 2.1: Obrazová data z projektu STARE: a) originální obraz, b) a c) jsou zlaté standardy, převzato z[4]	9
Obr. 2.2: Obrázky z databáze DRIVE: a) originální obraz, b) manuálně segmentovaný zlatý standard, převzato z [5].....	9
Obr. 2.3: z databáze HRF: a) obraz sítnice s onemocněním diabetické retinopatie, b) obraz s glaukomem.	10
Obr. 2.4: Obrazy z databáze HRF: a) obraz zdravého oka, b) ručně segmentovaný zlatý standard. Převzato z [6].	11
Obr. 3.1: Obrázek cévního řečiště po přizpůsobené filtraci, převzato z [14].	14
Obr. 4.1: Blokové schéma metody využívající perceptron.....	15
Obr. 4.2: Schéma perceptronu, převzato z [19]	16
Obr. 4.3: Vybavený – klasifikovaný snímek, před prahováním. (02h z HRF)	18
Obr. 5.1: Výsledky klasifikace u snímku 03h: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard	23
Obr. 5.2: Výsledky klasifikace u snímku 05h: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard	23
Obr. 5.3: Výsledky klasifikace u snímku 13dr: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard	25
Obr. 5.4: Výsledky klasifikace u snímku 15dr: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard	25
Obr. 5.5: Výsledky klasifikace u snímku 05g: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard	27
Obr. 5.6: Výsledky klasifikace u snímku 14g: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard	27

Seznam tabulek

Tab. 1.1: Technické specifikace fundus kamery Canon CF - 60 UVi, převzato z [3]	5
Tab. 5.1: Výsledky testování na smících zdravých pacientů	22
Tab. 5.2: Hodnoty ze zdravých snímků pro porovnání, převzato z [23]	22
Tab. 5.3: Výsledky testování na smících zdravých pacientů	24
Tab. 5.4: Hodnoty ze snímků s DR pro porovnání, převzato z [23]	24
Tab. 5.5: Výsledky testování na smících zdravých pacientů	26
Tab. 5.6: Hodnoty ze snímků s glaukomem pro porovnání, převzato z [23]	26

Úvod

Segmentované snímky cévního řečiště sítnice patří v dnešní době mezi přední diagnostické nástroje vhodné k diagnostice diabetické retinopatie a glaukomu. Obecně se dají využít jako předzpracování pro hlubší analýzu a detekci případných dalších patologií. Proto je potřeba metody segmentace a klasifikace cévního řečiště sítnice z fundus obrazů neustále zdokonalovat a rozvíjet pomocí nových poznatků v úpravě a klasifikaci obrazů.

Na obrázcích z fundus kamery je zobrazená vrstva s cévním řečištěm. Dále zde můžeme rozlišit tepny a cévy, optický disk, žlutou skvrnu a nervová vlákna. U pacientů, trpících onemocněním postihující cévní řečiště sítnice, můžeme vidět patologické nálezy, které jsou pro nás důležité při diagnóze a včasném zákroku.

Cílem této bakalářské práce bylo seznámit se s principy segmentace cévního řečiště ze snímků z fundu kamery a jednu metodu implementovat v programovém prostředí. Dále tato byla otestována, zhodnocena a porovnána s jinou segmentační metodou.

První kapitola je věnována fundus kameře, kterou jsou pořizovány snímky cévního řečiště. Během bakalářské práce proběhlo seznámení a vyzkoušení si pořídit snímek na fundus kameře. V druhé kapitole je pojednáváno o databázích, které se používají pro vývoj a hodnocení nově vytvořených metod segmentace a klasifikace. V této práci byla používána databáze HRF[6], která obsahuje obrazy s velkým rozlišením, proto je pro hodnocení a trénování klasifikace nejvýhodnější.

Dnes je segmentace již z velké části automatizovaná. Tato automatizovaná segmentace se převážně využívá v rámci preventivních screeningových vyšetření, uplatňující automatické počítačové analýzy, které zjednoduší včasné odhalení onemocnění. Poslední slovo má však v konečné fázi lékař, který potvrdí diagnózu navrženou pomocí automatického analyzátoru.

Segmentace může být provedena pomocí filtrování [7] dále pomocí neuronových sítí, které mají velmi zajímavé vlastnosti pro klasifikování, více v [8], [9], [10], [11]. A také pomocí přizpůsobené filtrace podle článku [14], z které využívám výstupní obrazy, pro moji metodu klasifikace.

Po konzultaci s vedoucím práce bylo dohodnuto, že bude tato práce věnována seznámení s prací s obrazy v programovém prostředí Matlab a s klasifikací pomocí neuronových sítí. Náplní této práce je proto klasifikace pomocí perceptronu. Více o používaném perceptronu je napsáno v kapitole 4.2

Perceptron využívá k učení delta pravidlo. Díky němu byl získán co nejvýhodnější vektor vah. Pomocí nastavených vah z vektoru příznaků jsou rozpoznávány jednotlivé stupně šedi, které dále budou roztríděny do dvou tříd na cévy a pozadí.

Klasifikovaný obraz je následně prahován pomocí Otsu metody [15], která využívá prahování pomocí tvaru histogramu a tím byl celý obraz rozdělen do dvou skupin cévy – bílé, pozadí – černé.

Algoritmus bylo potřeba otestovat a zhodnotit výsledky. To bylo provedeno na snímcích z databáze HRF a porovnáno s výsledky z [23]. Pro hodnocení byla použita sensitivita, specificita, accuracy – přesnost měření.

1. Obrazová data z fundus kamery Canon

CF- 60 UVi

Pro snímání očního pozadí se v dnešní době častěji než oftalmoskopy používají fundus kamery. Jsou to přístroje, které jsou schopny snímat obraz digitálně, díky tomu je jednodušší archivace snímků. Vyšetření, která jsou pomocí fundus kamery prováděny, jsou převážně diagnostika glaukomu a diabetické retinopatie. Na Obr 1.1 je pro názornost vyobrazena fundus kamera. [1]




Obr. 1.1: Fundus kamera Canon CF - 60 UVi převzato z [18]

1.1. Fundus kamera

První, co na fundus kameře uvidíme, je mechanická část, pomocí které fixujeme pacienta. Pacient si sedne na židličku, bradu položí na bradovou podložku a čelo si opře o předem připravenou opěrku. Fixace pacienta je důležitá, protože i malé pohnutí může mít za následek neostrost obrazu. Rameno kamery je pohyblivé, to nám umožní správné zaostření a vycentrování zaměřovacího křížku na střed zornice. [1], [2]

Uvnitř šasi se nachází hlavní část kamery, lze ji vidět i na Obr. 2.1 a jedná se o optický systém obsahující dva zdroje osvětlení. První zdroj slouží pro zaměření oka, zpravidla se jedná o diodu. Druhý je zdroj bílého světla, který má funkci blesku fotoaparátu. Tento digitální fotoaparát obsahuje CCD snímač, pomocí kterého se snímá výsledný obraz. K zaměřování středu zornice slouží druhý CCD snímač - kamera, ta snímá obraz pro operační panel obsluhy. Na panelu se provádí automatické nebo ruční nastavení parametrů obrazu, pomocí optiky

pro fokusaci a zaostření obrazu, různých filtrů (například zelený, červený), clon, apertury pro měření a iluminaci. [1], [2]



Obr. 1.2: Konstrukční schéma fundus kamery: 1 - zobrazovací jednotka; 2, 3, 4 - poziční jednotka; 5 - operační panel pro lékaře; 6 - objektiv, 7 – PC, převzato z [1]

1.2. Parametry fundus kamery Canon CF- 60 UVi

K této práci byla použita HRF databáze, která je poté blíže popsána v kapitole 2.3. Proto jsou zde uvedeny parametry fundus kamery, pomocí nichž je tato databáze pořízena.

Vlastnosti

- zobrazení FOV 30°, 40°, 60°
- přesný zaostřovací systém
- nastavení pracovní vzdálenosti
- automatická expozice na 35mm barevné fotografie
- automatické natáčení
- volitelně snímání s červeným a modrozeleným filtrem
- možnost fluorescenční a indocyanínové angiografie (automatické nastavování filtrů)
- režim snímání při úzké zornici
- vestavěný fotoaparát CANON EOS-20D s 8,2 Mpix CMOS snímačem
- možnost tisku snímků

Parametry převzaty z [3].

Technické specifikace


Tab. 1.1: Technické specifikace fundus kamery Canon CF - 60 UVi, převzato z [3]

Zorné pole FOV 60°, 40°, 30°	60°, 40°, 30°
Zvětšení u 35 mm filmu	1.7x (60°), 2.5x (40°), 3.4x (30°)
Velikost snímků	ø29 mm ´ 22 mm (35 mm film) ø75 mm ´ 57 mm (Polaroid film)
Minimální průměr čočky	Ø 4 mm
Pracovní vzdálenost	45 mm
Rozsah dioptrií	-10 to +12D (bez kompenzační čočky) -6 to -27D (záporná kompenzační čočka) +9 to +32D (kladná kompenzační čočka)
Nastavení dioptrií obsluhy	± 5D
Zdroj bílého světla	300 W xenonová výbojka
Možnosti natáčení	Vertikálně: 38 mm Dopředu/dozadu: 70 mm Vpravo/vlevo: 120 mm Pohyb tváře: 65 mm
Rozměry	320 mm x 560 mm x 565 mm
Váha	26 kg

1.3. Vlastnosti barevných snímků z fundus kamery

Z anatomického hlediska najdeme na snímcích z fundus kamery žlutou skvrnu (fovea), ta se nachází uprostřed, viz Obr. 1.3. Na pravé straně můžeme dále vidět optický disk, ze kterého, jak je patrné, vychází všechny cévy (tepny a žíly), které tvoří zásobovací cévní systém sítnice. Pozice očního disku a rozložení cévního řečiště je velmi důležité při diagnostice očních onemocnění, proto je kvalita snímku rozhodující pro diagnostiku. [3], [20]

Na snímcích můžeme vidět i nervová vlákna, která jsou charakteristická světlým žíháním. Tyto vlákna jsou nejvíce patrné v místě optického disku, protože pomocí zrakového nervu opouští oko. Ve skutečnosti je však jejich největší koncentrace ve středu oka, kde se nachází žlutá skvrna. [3], [20]



Obr. 1.3: Snímek zadní části sítnice z databáze HRF


Snímky jsou uloženy v RGB kódování, to znamená, že se každý snímek skládá ze tří barevných kanálů. Na Obr. 1.4 je vidět, že nejvíce informací nám poskytne zelený kanál, který je využit k přizpůsobené filtraci, ze které je používán výstup. Také je zde vidět největší rozdíl cév vůči pozadí a i ostatní anatomické části oka jsou zde dobře rozpoznatelné a lokalizovatelné. [3]



Obr. 1.4: Zobrazení ve třech kanálech: a) červený kanál, b) zelený kanál, c) modrý kanál

1.4. Cévní struktury na snímcích sítnice

Pro popis struktury cév budou použity snímky v zeleném kanálu, protože se zde projeví nejlepší kontrast mezi pozadím a cévou. Cévy se postupně od optického disku, ze kterého vychází, zmenšují, viz Obr. 1.5.



Obr. 1.5: Struktura cévního řečiště na sítnici, v zeleném kanálu.

Zejména širší cévy obsahují uprostřed tzv. centrální reflex, který poznáme podle světlého proužku uvnitř cévy. Dle anatomického hlediska jsou v cévním řečišti tenčí tepny a tlustší žíly. Tepny jsou světlejší a žíly tmavší a tlustší. Pro diagnostiku kardiovaskulárních chorob je zaveden poměr šířky tepna/žíla, u zdravého jedince bývá tento poměr 2:3. Detail lze vidět na Obr. 1.3. [3], [21]



Obr. 1.6: Detail cév, můžeme zde vidět tepny, žíly a centrální reflex.

2. Databáze obrazů z fundus kamery pro segmentaci cévního řečiště


Databáze obrazů obsahují, mimo jiné, i zlaté standardy, které se používají pro porovnání různých metod segmentace. Zlatý standart pro segmentaci cévního řečiště by měl reprezentovat nejlepší výsledky segmentační metody, se kterými se porovnávají nové nebo zdokonalené metody segmentace. Existuje několik databází používajících se na celém světě. [3]

2.1. Projekt STARE

Tento projekt započal v roce 1975 na kalifornské universitě pod vedením doktora Michaela Goldbauma. Dnes už se počet pracovníků pohybuje okolo třiceti a jedná se převážně o lékaře a inženýry. Data byla získána z Shiley Eye Center na universitě v Kalifornii, San Diegu a Veterans Administration Medical Center v San Diegu. [4]

Cílem projektu je zjednodušení diagnostiky očních onemocnění pomocí databáze různých očních onemocnění a zlepšení automatické diagnostiky onemocnění. Doba trvání tohoto projektu nám umožňuje sledovat různé degradace v čase a také zlepšit diagnózu. Projekt má snahu vyvinout nástroj, který bude automaticky diagnostikovat oční onemocnění. Snaží se ho vytvořit tak, aby se choval jako skutečný lékař, který vytvoří, v nejlepším případě, stejnou diagnózu. Analýza se skládá ze dvou funkčních bloků. V prvním případě je potřeba obraz upravit a zpracovat do vhodné podoby, proto se v projektu řeší problém segmentace cévního řečiště, lokalizací očního disku, aby šel automaticky diagnostikovat. Druhý blok má za úkol provést návrh vhodné diagnózy. Ukázky obrazových dat z projektu STARE, viz Obr. 2. 1. [3],[4]

V databázi nalezneme 402, ke každému jsou dva možné typy zlatého standardu, které obsahují detailní rozměření anatomických struktur nacházející se na sítnici. Tohoto se využívá pro sledování časové progrese patologií. Snímky jsou uloženy ve formátu PPM, jejich rozlišení je 700×605 pixelů a barevná hloubka je 8 bitů. Snímky mají FOV 60° pro standardní panoramatický snímek a 10° pro snímání detailů. [4]



a)

b)


c)

Obr. 2.1: Obrazová data z projektu STARE: a) originální obraz, b) a c) jsou zlaté standardy, převzato z[4]

2.2. Databáze DRIVE

DRIVE je zkratka pro Digital Retinal Images for Vessel Extraction, což v překladu znamená digitální sítnicové obrazy pro cévní zvýraznění. Tato databáze byla vytvořena v roce 2004, aby sloužila výzkumným organizacím k testování a porovnávání jejich segmentačních metod. Proto je volně ke stažení. Výsledky jednotlivých metod jsou zveřejněny pro porovnání na stránkách databáze. [5]

Databáze obsahuje 40 snímků rozdělených po 20 snímcích do skupiny k trénování a testování metod. Snímky pochází ze screeningového programu diabetu v Nizozemsku. Snímky jsou pořízeny pomocí digitální fundus kamery Cannon CR5, která je ne-mydriatická s 3CCD čipem a 45° FOV – Field of View. Rozlišení snímků je 564 × 584 pixelů a jsou uloženy ve formátu JPEG s 8 bitovou barevnou hloubkou. Obrázky jsou ořezané pomocí masky, která vychází z FOV (Field of View) na kruhový průměr přibližně 540 pixelů. Na Obr. 2.2 je ukázka originálního snímku a zlatého standardu v podobě manuálně segmentovaného snímku. [3],[5]



a)

b)

Obr. 2.2: Obrázky z databáze DRIVE: a) originální obraz, b) manuálně segmentovaný zlatý standard, převzato z [5]


2.3. Databáze HRF

Všechny výše uvedené databáze mají nízké rozlišení originálních snímků a zlatých standardů, které jsou pro testování nových metod velmi nevýhodné. Tímto může být v případě použití databáze s nízkým rozlišením problém s detaily ve snímku, i když bude vypadat, že metoda v porovnání se zlatým standardem funguje kvalitně. [23]


Proto vznikla nová databáze HRF, neboli High-Resolution Fundus Image Database, jejíž rozlišení je 8 Mpix a díky tomu je zachována dostatečná rozlišovací schopnost beze změny velikosti obrazu. Další výhodou je, že obsahuje jak zdravé pacienty, tak i nemocné s diabetickou retinopatií a glaukomem (zelený zákal). V každé skupině je 15 snímků. Díky vysokému rozlišení jsou mnohem více vidět tenké cévy a konce cév. Rozlišení zlepšuje i včasnou diagnostiku lézí, které můžeme začít dříve léčit. [6], [23]

Databáze byla získána mydriatickou fundus kamerou Canon CF-60 UVi s připojeným digitálním fotoaparátem Canon EOS-20D s 60° FOV a rozlišením 3504 × 2336 pixelů. Všechny obrázky jsou uloženy ve formátu JPEG s 24 bitovou barevnou hloubkou. Zlaté standardy byly vytvořeny ruční metodou, které přes časově náročný proces získají velmi dobrou kvalitu. Dále databáze obsahuje také masky, určující FOV jednotlivých snímků. Již na Obr. 2.3 je vidět lepší rozlišení. [6], [23]

Tato databáze pochází z Ústavu biomedicínského inženýrství, Fakulty elektrotechniky a komunikací, VUT v Brně. Ve spolupráci s oční ordinací MUDr. Tomáše Kuběny ve Zlíně, díky které byla testovací sada obrázků poskytnuta.



Obr. 2.3: z databáze HRF: a) obraz sítnice s onemocněním diabetické retinopatie, b) obraz s glaukomem.
Převzato z [6]



a)

b)

Obr. 2.4: Obrazy z databáze HRF: a) obraz zdravého oka, b) ručně segmentovaný zlatý standard. Převzato z [6].

3. Známé způsoby řešení problematiky segmentace cévního řečiště

Dnes je na téma segmentace cévního řečiště ze snímku sítnice napsáno v mnoho odborných článcích. Lze je rozdělit do několika kategorií podle přístupu dané metody.

3.1. Sledování

V článku [7] je popsána klasifikace založená na sledujícím algoritmu, který zvýší výkon třídění základní techniky s prodlužujícím se sledovacím oknem, na kterém se třídění uskutečňuje a uplatní silný odhad z lokálního sestavení cévy.

3.2. Pomocí neuronových sítí

Dá se také nazvat jako metoda segmentace pomocí učení, na kterou se tato práce nejvíce zaměřuje, protože zde budou uvedeny důležité poznatky z těchto článků.

Sítnicová členitost cévní metody, založené na buněčných neuronových sítích (CNNs), je navrhovaná v článku [8]. Návrh neuronové sítě se vyznačuje virtuálním šablonovým zvětšením získaným skrz vícestupňovou operaci. To je založené na lineárním prostoru-stálých 3×3 šablonách a může být zjištěné použití existujících modelů čipu, jako je ACE16K. Navrhovaný vzorek je schopný vykonat segmentaci cévy v krátkém výpočetním čase. Toto bylo testováno na veřejně dostupné databázi barevných obrazů sítnic, použitím provozních charakteristik přijemce. Výsledky simulace ukazují dobrý výkon srovnatelný s nejlepšími existujícími způsoby. K dalším prací od Ricciho a Perfettiho [9] patří práce, zabývající se Line detektorem, kde jde o vektorové zpracování pro přiřazení jednotlivých pixelu k cévnímu řečišti.

Další metoda [10] využívá kombinaci 2D Gaussova přizpůsobeného filtru, zjednodušené PCNN (Pulzně vázaná neuronová síť) a rychlého 2D-Otsu algoritmu. První, 2D Gaussův přizpůsobený filtr, zvětší obrazy na sítnici a zjednodušený PCNN je použitý k oddělení na úseky krevní cév porovnáním se sousedními neurony. Poté rychlý 2D-Otsu algoritmus, který hledá nejlepší práh pro dokončení segmentace.

Metodu Marín a kol [11], používající pro segmentaci 7 - mi dimenzionální matici. Tato metoda překonává všechny dosavadní metody segmentace, zejména při použití patologických snímků. Užívá neuronovou síť pro třídění a vypočítání právě 7 – rozměrných vektorů skládajících se z šedých-úrovní. Metoda byla zhodnocená právě na veřejně dostupných DRIVE a STARE databázích, které jsou široce používané za účelem testování nových algoritmů. Metoda testovaná na obou souborech obrazů je lepší, než další existující řešení v literatuře. Zvláště přesná pro cévní rozpoznání obrazů ze STARE. Její účinnost a robustnost s různými obrazovými podmínkami, její jednoduchost a rychlá implementace, vytvoří tuto cévní seg-

mentaci vhodnou pro počítačové rozборы obrazů na sítnice, jako automatizované třídění pro včasné nalezení diabetického onemocnění sítnice.

3.3. Filtraci

Základní filtrační metody velmi dobře popsali ve své práci Zana a Klain [12], kteří vytvořili algoritmus kombinující morfologické filtry a hodnocení specifického tvaru cév pro sestavení masky ze základních znalostí cévních struktur, která slouží pro oddělení cévní struktury od pozadí. Ve své práci používají metody matematické morfologie pro zvýraznění cév a dalších vlastností v cévních strukturách.


Další metoda, patřící do kategorie pomocí filtrace, používá přizpůsobený filtr pro odhalení cévy, článek popisující metodu poskytující přesnější výsledky se jmenuje *Detekce cévního řečiště v ophthalmoskopických obrazech použitím přizpůsobené filtrace a algoritmu mravenčí kolonie* [13]. Používání tohoto filtru nedokázalo obnovit všechny cévy (zvláště kapilární). Tento článek popisuje nový přístup, který je navrhnout, aby překonal nedostatek z přizpůsobené filtrace. Navrhovaná metoda je hybridní model přizpůsobeného filtru a algoritmu mravenčí kolonie. Navrhovaná metoda ukazuje své úspěchy při používání dobře známých očních obrazů v DRIVE databáze.

Druhá metoda segmentace cévního řečiště automatickou metodou s využitím přizpůsobených filtrů [14]. Tato metoda bude více rozpracována, protože pro je použita pro klasifikaci, jako vstup dat z této filtrace. Ukázka snímku vyfiltrovaného přizpůsobenou filtrací lze vidět na Obr. 3.1.

Principem metody [14] je využití korelace mezi lokální oblastí v obraze, která obsahuje částí cévy a filtrační maska. K navržení této masky bylo potřeba měření jasového profilu cév v obraze z databáze HRF uvedené v kapitole 2.3. Poté máme pro filtraci definováno pět 2D matic, které představují právě dané filtry. Při tvorbě těchto matic se vychází z rozdělení cév na pět různých šířek cév. Vstupem je RGB obraz, ze kterého při filtraci využíváme pouze zelenou G složku.

Vstupní data jsou postupně konvolovány natáčenými filtračními maskami, kde krok natáčení je v rozmezí 0° až 165° s krokem 15° . Touto konvolucí získáme 60 parametrických obrazů, představující dílčí odezvy, ze kterých je složena celková odezva - obraz. Sloučení provádíme tak, že lokální maximální odezva je vybraná mezi 60 hodnotami pro každý pixel. Vyplyvající obraz tak obsahuje místní informaci o odhadovaném stupni cévní existence. Tento obraz může být okamžitě prahován, nalezením prahu podle standardní Otsu metody [15]. Některé krátké části cév (převážně tenké části) jsou jasně chybějící a jsou poté doplněny podle souvislé podmínky v oblasti kolem konce cévy. Je také pátráno po možném pokračování v přibližném směru očekávaného pokračování. V oblasti kruhového sektoru vhodné hloubky


a šíře je pátráno po pokračování cévy a v případě nalezení se lineární prvek propojí v souvislou cévu s cévní šíří z výchozího konce. Na závěr se morfologicky očistí dvojité obrazy, který umožňuje odstranění malých nebo krátkých artefaktů kvůli šumu nebo dalším obrazovým strukturám, které nepatří cévnímu stromu.



Obr. 3.1: Obrázek cévního řečiště po přizpůsobené filtraci, převzato z [14].

4. Návrh metody segmentace s využitím perceptronu

Pro klasifikaci cévního řečiště bylo v bakalářské práci využito umělého neuronu s učením pomocí delta pravidla, v kombinaci s prahování Otsu algoritmem a manuálním prahováním.



Obr. 4.1: Blokové schéma metody využívající perceptron

4.1. Teorie umělých neuronů a neuronových sítí

Neuronové sítě jsou jedno z odvětví umělé inteligence, které se v medicíně poslední roky rozvíjí. Je to převážně kvůli jejich zajímavým vlastnostem, kterých bude v této práci využito ke klasifikaci cévního řečiště. McCulloch a Pitts poskytli první princip matematického a logického zacházení s jednoduchými neurony. Donald Hebb roce 1949 navrhl učící pravidlo, které uvedl v knize „The Organization of Behaviour“. Inspiroval se myšlenkou podmíněných reflexů, kde se domnívá, že jsou vlastnostmi jednotlivých neuronů. Frank Rosenblatt v 60. letech vynalezl tzv. perceptron, čím dokázal zobecnit McCullochův a Pittsův model pro reálné parametry. Pro tento model navrhl učící algoritmus, který je ekvivalentem delta pravidla. Tímto modelem dokázal, že pro daná tréninková data nalezne po konečném počtu kroků odpovídající váhový vektor parametrů nezávisle na jeho počátečním nastavení. Dále v roce 1962 vytvořil první neuronovou síť.[16],[17]

Vlastnosti

Mezi hlavní vlastnosti neuronových sítí patří schopnost učit se a tím měnit své parametry a struktury, pro optimalizaci požadovaných výsledků. Můžeme rozlišovat dva typy učení, učení na příkladech, nazýváno učení s učitelem. Druhý typ učení je bez něj a probíhá pouze kompenzací chyb, které udělala a tím se co nejvíce přiblížit zadání úkolu. Proto obsahuje zpětnou vazbu sloužící pro kontrolu provedení daného úkolu a případnou změnu parametrů potřebných k vykonání zadání. Další zajímavou vlastností je predikce, což znamená, že se neuronová síť snaží vytvořit vlastní vnitřní model, napodobující skutečný systém. Odolnost vůči chybám patří také mezi hlavní vlastnosti a pomocí zpětné vazby je schopná reagovat na drobné odchylky. Poslední typickou vlastností je rychlost zpracování, díky paralelnímu zpracování.[16],[17]


Využití neuronových sítí

Lze využít jako:

- **Asociativní paměti** – odpovídají vzorem, který je asociován se vstupním vzorem. Dva typy autoasociativní a heteroasociativní.
- **Klasifikátory** – pomocí učení rozpoznají vstupní vzor a přiřadí ho do vybrané třídy, na výstupu jsou zpravidla dvě třídy – patří a nepatří, logická jednička a logická nula. Hlavní úloha je zařadit správně vzor na základě podobnosti.
- **Aproximátory** – schopny predikovat událost, jejich funkce spočívá ve schopnosti vlastního vnitřního modelu na základě vstupních informací, tím se aproximuje skutečný systém.

4.2. Popis neuronu použitého v této práci

Jako klasifikátor byl používán neuron se dvěma vstupy a jedním binárním výstupem. Tento klasifikátor se také nazývá jednoduchý perceptron, jeho schéma na Obr. 4.1. Jeden vstup reprezentuje vektor příznaků x . V tomto případě jsou to stupně šedi, kde x_1 je vektor vstupních hodnot a x_2 je požadovaná odezva, a druhý vstup d je požadovaný výstup. Vektor x_1 je stvořen hodnotami obrazu metodou přizpůsobené filtrace [14]. Vstupy x_2 a d jsou totožné, jde o hodnoty ze zlatého standardu ručně segmentovaného, protože pro učení bylo potřeba předem vědět, do jaké třídy hodnota patří. Výstup je binární nabývá hodnot 0 a 1, což signalizuje příslušnost vstupního vektoru k třídě cévy nebo pozadí. [16],[17]



Obr. 4.2: Schéma perceptronu, převzato z [19]

4.3. Učení s učitelem

Pomocí učení bylo snahou nelézt vhodné váhy pro váhový vektor w , aby šlo, pomocí vhodného váhového vektoru, klasifikovat nové obrazy. Proto se nejdříve musela naučit na vstupních vektorech x a d , u kterých bylo jednoznačně jasné, do jaké třídy patří, zda céva nebo pozadí. Učení je iterační proces, který po projití tréninkové dvojice (x, d) , provede adaptaci vah. [17]

K adaptaci vah bylo použito **delta pravidlo**, u kterého závisí na velikosti odchylky výstupu y od požadovaného výstupu d , dále závisí na parametru učení μ a vstupním vektoru x . Při nastavování parametru učení nesmíme překročit velikost větší než 1, tato hodnota totiž ovlivňuje adaptaci vah. [17],[16]

Samotné učení probíhá v epochách, čímž můžeme rozumět projití všech učebních dvojic neuronovou sítí. Po skončení každé epochy učení se provede rekapitulace, kolik učebních vstupních vektorů bylo správně klasifikováno (resp. kolikrát se během epochy musely korigovat váhy), tímto se zjistí, zda má síť dále pokračovat v učení. [17]

Následující dva algoritmy byly využívány ke klasifikaci, v programu implementovaném v prostředí Matlab.

Algoritmus učení

- Nejdříve je potřeba vložit jako vstupní vektor obraz, k němu odpovídající zlatý standard a jím odpovídající výstup nabývající hodnot 0 a +1.
- Poté je potřeba nastavit parametry, hlavně váhy a práh na malé hodnoty.
- Výpočet aktuálních výstupu vypočítáme vzorcem:

$$y(t) = f\left(\sum_{i=1}^N w_i(t)x_i(t) - \vartheta\right) \quad (4.1)$$


Funkce f má tvar funkce signum, která se posunuje o práh ϑ

- Přizpůsobení vah, váhy se upravují dle odchylky výstupu od požadovaného vstupu, jsem použil vzorec:

$$w_i(t+1) = w_i(t) + \mu[d(t) - y(t)]w_i(t), \quad 1 \leq i \leq N \quad (4.2)$$

Algoritmus vybavování

Výstup z perceptronu se získá pomocí vzorce (4.1). K vypočítání výstupu klasifikace, stačí dosadit váhy a práh, který jsme získaly jako výstup z algoritmu učení a za x vložíme obrázek, který chceme klasifikovat. A na výstupu y dostaneme vektor výstupních hodnot.



Obr. 4.3: Vybavený – klasifikovaný snímek, před prahováním. (02h z HRF)

4.4. Prahování

Prahování bylo využito k závěrečné úpravě obrazu, kdy se všechna obrazová data převádí na černobílý obraz. To znamená, že byl převeden z obrazu ve stupních šedi na binární obraz, kde jsou cévy zastoupeny logickou jedničkou - bílá barva a pozadí je černé - logická nula. K prahování je v této práci využit Otsu algoritmus.

Tento algoritmus byl navržen v roce 1979 a hledá nejlepší mez mezi stupni šedi v histogramu. Je to široce používaný nástroj segmentace obrazu pro extrakci objektů od jejich pozadí. Nejdříve se však nedařilo nacházet vhodný práh pro obrazy s nízkým poměrem signál šum, protože hledání prahu záviselo pouze na úrovni šedého histogramu obrazu. Nicméně, nynější Otsu algoritmus může fungovat dobře i na obrazy s nízkým poměrem signál šum a nízkým kontrastem, protože využívá informace o hladině šedi, místo informace o jednotlivých pixelech. [15]

V této práci byl používán Otsu algoritmus k automatickému prahování obrazů. Informace o hladině šedi získává pomocí tvaru histogramu. Algoritmus předpokládá, že obrázek, který je prahován, obsahuje dvě třídy pixelů nebo bimodální histogram. V této práci jde o případ obrazu se dvěma třídami. Algoritmus počítá optimální práh, který je rozhraním pozadí – céva.[15]

4.5. Implementování aplikace

Aplikace byla implementována - naprogramována v programovém prostředí Matlab. Skládá se s několika částí: učení, aktivační funkce, funkce vybavování a programu pro hodnocení výsledků.

První část, používaná k učení, si nejdříve načte hodnoty libovolného snímku, který jsou využívány k učení a poté je potřeba k nim načíst příslušný zlatý standart, který reprezentuje požadovaný výstup. Pak si ze snímku vybereme libovolně velký výřez obsahující jak tlusté cévy, tak ty nejtenčí cévní struktury. Poté tyto výřezy převede na vektory, které jsou pro proces učení jednodušší na zpracování. Po nastavení všech parametrů, jako jsou váhové hodnoty, práh, krok učení, atd. je v cyklu `for` vykonáno učení neuronu za pomoci aktivační funkce a rovnice 4.1.

Aktivační funkci je využíváno sigmoidu, ale je možné použít i skokovou funkci, obě tyto funkce jsou v rozsahu hodnot na ose y od 0 po 1. Učení spočívá ve změně nastavení vstupních parametrů, byly upravovány váhy a práh – theta. Na závěr je počítána a zobrazována hraniční přímka, která značí hranici mezi cévami a pozadím. Tato přímka byla využívána pro nastavování vhodných parametrů učení, hodnota přímky na ose y nám znázorňuje prahovou hodnotu rozhraní céva pozadí, která byla využívána pro krok vybavování.

Klasifikován je celý obrázek, pixel po pixelu, vybavování bylo provedeno pomocí cyklu `for`. Celý proces vybavování-klasifikace byl prováděn jen uvnitř masky, aby nedocházelo ke zbytečné klasifikaci okrajů. Proto je potřeba nahrát příslušný obrázek a k němu vhodnou masku. Masku bylo potřeba nejdříve pomocí příkazu `imerode` zvětšit, protože po použití snímků z přizpůsobené filtrace dochází při klasifikaci na rozhraní z masky k vytvoření nežádoucích artefaktů.

V této aplikaci bylo pro prahování využito automatické funkce v programovém prostředí Matlab, která vychází z Otsu algoritmu. Nejdříve byl, spočítám práh pomocí příkazu `level = graythresh(I)`, poté byl obraz pomocí `BW = im2bw(I,level)` naprahován. Výstupní obraz BW nahrazuje všechny obrazové body ve vstupním obraze (I), které jsou větší než práh (level) za hodnotu 1 (bílá) a všechny ostatní pixely nahrazuje na hodnotu 0 (černá). Nakonec jsou pomocí příkazu `bwareaopen` odstraněny všechny části, které byly menší, než 1000 pixelu.

Nakonec bylo vše otestováno na databázi HRF a pomocí jednoduchého algoritmu byly vypočítány hodnoty pro hodnocení algoritmu, jsou to TP, TN, FP, FN. Tyto hodnoty byly dále zpracovávány pomocí programu Microsoft Excel.

5. Diskuze a zhodnocení výsledků

Klasifikační metodu bylo potřeba zhodnotit. Nejdříve bylo potřeba získat hodnoty testování, které bylo provedeno na databázi snímků HRF, která je více popsána v kapitole 2.3., poté byly výsledky zhodnoceny. Jestliže všechny hodnoty v následujících tabulkách vydělíme číslem 100, dostaneme výsledné hodnoty v procentech.

5.1. Kritéria k hodnocení

Pro hodnocení je potřeba stanovit si hodnotící kritéria, pomocí kterých dále probíhá samotné hodnocení výsledků práce.

Nejdříve si nadefinujeme následující pojmy používané při hodnocení:

- TP - True Positive (správně detekovaný bílý pixel): bílý pixel byl očekáván a detekován
- FP - False Positiv (špatně detekovaný bílý pixel): byl očekáván černý pixel, ale detekován byl bílý
- TN - True Negativ (správně detekovaný černý pixel): černý pixel byl očekáván a detekován
- FN – False Negativ (špatně detekovaný černý pixe): byl očekáván bílý pixel, ale detekován byl černý

Sensitivita

Sensitivita, nebo také TPR – True Positive Rate, uvádí míru pravdivé positivity. Je to pravděpodobnost, že bílý pixel má patřit do cévního řečiště. Sensitivita je vyjádřena pomocí rovnice[22]:

$$TPR = \frac{TP}{TP+FN} \quad (5.1)$$

Specificita

Specificita, neboli TNR - True Negative Rate, je popsána jako míra pravdivé negativity. Uvádí pravděpodobnost, že černý pixel má patřit do pozadí. Popisuje ji rovnice[22]:

$$TNR = \frac{TN}{TN+FP} \quad (5.2)$$

Accuracy – přesnost měření

Jde o odchylku od skutečné hodnoty měřené veličiny. Vypočte se dle vztahu 5.3[3]:

$$ACC = \frac{TP+TN}{TP+FN+TN+FP} \quad (5.3)$$

Jestliže se přesnost měření přibližuje hodnotě 1 (resp. 100 %), tím je měření mnohem přesnější, a naopak. Samotná přesnost měření závisí na přesnosti použitého algoritmu hodnocení, v tomto případě tedy senzitivity, specificity a schopnosti počítat správné hodnoty. [3].

5.2. Výsledky testování a zhodnocení metody

Snímky zdravých pacientů

Tab. 5.1: Výsledky testování na smících zdravých pacientů


	SE	SP	ACC
h01	0,7562	0,9560	0,9148
h02	0,8680	0,9355	0,9220
h03	0,7498	0,9377	0,8976
h04	0,8527	0,9255	0,9116
h05	0,7183	0,9808	0,9364
h06	0,7495	0,9705	0,9251
h07	0,8736	0,9341	0,9232
h08	0,7219	0,9769	0,9251
h09	0,7668	0,9555	0,9258
h10	0,6889	0,9764	0,9263
h11	0,7681	0,9751	0,9360
h12	0,7724	0,9718	0,9295
h13	0,8180	0,9283	0,9089
h14	0,7273	0,9597	0,9186
h15	0,7433	0,9722	0,9360
průměr	0,7717	0,9571	0,9225
směrodatná odchylka	0,0564	0,0198	0,0108

minimální a maximální hodnota je vyznačena tučně


Tab. 5.2: Hodnoty ze zdravých snímků pro porovnání, převzato z [23]

	SE	SP	ACC
průměr	0,7861	0,9750	0,9539
směrodatná odchylka	0,0392	0,0065	0,0075

Snímky zdravých pacientů byly klasifikovány dostatečně, i když je u této metody vidět na Obr. 5.1 a 5.2 nižší schopnost klasifikace nejmenších cévních struktur. Průměr hodnoty SE - sensitivity jsou v této práci 0,7717, což značí pravděpodobnost, že bílý pixel je správně klasifikován, jako céva. Rozhodující je však hodnota ACC, jenž udává přesnost hodnocení a počítání SE a SP. Průměr ACC značí, že přesnost testování je více, než 92 %, v porovnání s hodnotou z metody [23], která je přibližně 95 %, není takový rozdíl, ale snahou je, aby se hodnota přiblížila co nejvíce 1. Celkově je klasifikace, pomocí [23] u zdravých pacientů, lepší.



Obr. 5.1: Výsledky klasifikace u snímku 03h: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard



Obr. 5.2: Výsledky klasifikace u snímku 05h: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard

Snímky pacientů s diabetickou retinopatií

Tab. 5.3: Výsledky testování na smících zdravých pacientů


	SE	SP	ACC
dr01	0,4914	0,9721	0,9226
dr02	0,7732	0,9391	0,9177
dr03	0,7797	0,9356	0,9166
dr04	0,6510	0,9532	0,9187
dr05	0,7818	0,9470	0,9262
dr06	0,6251	0,9084	0,8652
dr07	0,7421	0,9384	0,9076
dr08	0,8178	0,8881	0,8774
dr09	0,5301	0,9713	0,9109
dr10	0,6855	0,9540	0,9065
dr11	0,7521	0,9422	0,9096
dr12	0,6834	0,9548	0,9175
dr13	0,7885	0,9656	0,9296
dr14	0,7778	0,9071	0,8872
dr15	0,8338	0,8616	0,8579
průměr	0,7142	0,9359	0,9047
směrodatná odchylka	0,1023	0,0316	0,0223

minimální a maximální hodnota je vyznačena tučně


Tab. 5.4: Hodnoty ze snímků s DR pro porovnání, převzato z [23]

	SE	SP	ACC
průměr	0,7463	0,9619	0,9445
směrodatná odchylka	0,0566	0,0077	0,0084

Dále byly klasifikovány snímky pacientů s diabetickou retinopatií, jejichž výsledky se ukázaly jako nepřesné. U této metody je již na první pohled zřejmá malá schopnost klasifikace nejmenších cévních struktur, a to z obrázků 5. 3. a 5. 4. Průměrná hodnota SE senzitivity se zde pohybuje okolo 71 %. Tato hodnota nám značí pravděpodobnost, kdy je bílý pixel správně klasifikován jako céva. Rozhodujícím ukazatelem je zde hodnota ACC, díky které zjišťujeme přesnost hodnocení a počítání SE a SP. Průměrná hodnota ACC poukazuje na 90 % přesnost testování. V porovnání s hodnotou z metody [23], jejichž hodnota dosahuje 94 %, je zřejmý 4 % rozdíl. Tento je způsobován danými příznaky diabetické retinopatie, v tomto případě je tedy klasifikace složitější.



Obr. 5.3: Výsledky klasifikace u snímku 13dr: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard



Obr. 5.4: Výsledky klasifikace u snímku 15dr: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard

Snímky pacientů postižených glaukomem

Tab. 5.5: Výsledky testování na smících zdravých pacientů


	SE	SP	ACC
g01	0,6847	0,9564	0,9197
g02	0,6661	0,9646	0,9197
g03	0,5734	0,9806	0,9331
g04	0,6460	0,9740	0,9313
g05	0,6717	0,9776	0,9372
g06	0,6921	0,9713	0,9327
g07	0,7162	0,9570	0,9253
g08	0,7812	0,9421	0,9200
g09	0,6784	0,9642	0,9260
g10	0,7918	0,9349	0,9159
g11	0,7126	0,9569	0,9191
g12	0,7566	0,9428	0,9117
g13	0,7080	0,9494	0,9163
g14	0,7241	0,9311	0,9015
g15	0,6747	0,9638	0,9209
průměr	0,6985	0,9578	0,9220
směrodatná odchylka	0,0545	0,0153	0,0092

minimální a maximální hodnota je vyznačena tučně


Tab. 5.6: Hodnoty ze snímků s glaukomem pro porovnání, převzato z [23]

	SE	SP	ACC
průměr	0,7900	0,9638	0,9497
směrodatná odchylka	0,0318	0,0069	0,0061

Jako poslední byly klasifikovány snímky pacientů s postižením glaukomu. Průměrná hodnota SE sensitivity, tedy pravděpodobnost, kdy je bílý pixel správně klasifikován jako céva, dosahuje necelých 70 %. Sensitivita SE se sice snížila, ale specifita SP je téměř stejná, jako hodnota u klasifikace snímků u zdravých pacientů. Průměrná hodnota ACC, tedy rozhodující ukazatel pro přesnost hodnocení a počítání SE a SP, ukazuje na 92 % přesnost při testování. V porovnání s hodnotou z metody [23], která činí 95 % je zde pouze 3 % odchylka. Při testování nebyl tento algoritmus příliš účinný, protože se zde zvýrazní mnoho příznaků již zmíněného glaukomu, tedy zeleného zákalu.



Obr. 5.5: Výsledky klasifikace u snímku 05g: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard



Obr. 5.6: Výsledky klasifikace u snímku 14g: a) klasifikovaný snímek, b) prahování pomocí Otsu algoritmu, c) zlatý standard

6. Návod k aplikaci

Program se skládá ze čtyř částí `uceniNN.m`, `vybavovani_z_NN_cely_otsu.m`, `hodnoceni.m` a `aktiv_fce.m`, která je vyvolána pomocí funkce `uceniNN.m`. Všechny části se spouští pomocí tlačítka `run` na liště nástrojů v Editor okně.

Funkce `uceniNN.m`

Tato část musí být spuštěna jako první, zde probíhá učení perceptronu.

1. První je potřeba nastavit, snímek pro učení a k němu příslušný standart. Důležité je správně napsat názvy, jak je máme uložené.

Příklad: Hodnoty nastavené pro učení ze zdravého snímku 01. Fialová část, představuje název snímků, která se mění, pokud chceme vložit jiný snímek.

```
load 01_h.jpg_mfr.mat    snímek pro učení
ZL = imread('01_h.tif')  zlatý standart
```

2. Vybereme si souřadnice, ze snímku z kterých bude perceptron měnit své váhy a práh.

Příklad: `vyrez_x = 2001:2500;` x souřadnice
`vyrez_y = 1571:1970;` y souřadnice

3. Dále je možné měnit váhy, práh a parametry učení. Tyto parametry doporučuji neměnit, protože klasifikace je s těmito hodnotami nejúčinnější.

Hodnoty použité ke klasifikaci: `w = [0;1]` váhy
`theta = 0.1` práh

Parametry učení

`mu = 0.5` krok učení
`Ep = 0.01` přípustná kvadratická odchylka

4. Můžeme spustit

Funkce `vybavovaniNN_a_prahovani.m`

Tato část se spouští jako druhá, až se dokončí algoritmus učení, zde probíhá klasifikace a prahování.

1. První je potřeba nastavit snímek, který chceme klasifikovat a k němu příslušnou masku, která nám vymezí oblast klasifikace a zlatý standart pro hodnocení. Důležité je napsat názvy správně tak, jak jsou uloženy.

Příklad: Nastavení hodnot snímku, masky a zlatého standardu, který budeme klasifikovat. Jde o zdravý snímek 03. Fialová část, představuje název, v případě změny snímku se mění.

```
load 03_h.jpg_mfr.mat      snímek který se bude klasifikovat
M = imread('03_h_mask.tif') maska
ZLT = imread('01_h.tif')    laty standart
```

2. Na závěr můžeme měnit počet pixelů v příkazu, který nám odstraní ze snímků objekty, které se vytvoří prahováním. Tuto hodnotu nám představuje červené číslo.

```
BW2=bwareaopen(BW,10000)    příkaz pro odstranění objek-
tů menších než nastavený počet pixelů
```

3. Můžeme spustit

Funkce hodnoceni.m

Tato funkce slouží pouze k zjištění hodnot potřebných pro hodnocení. Není zde potřeba nic nastavovat a ani měnit. Stačí ji jen spustit po provedené klasifikaci pomocí funkce vybavovniNN_a_prahovani.m.

7. Závěr

Cílem této práce bylo aplikovat klasifikátor, pomocí kterého se budou klasifikovat snímky z fundus kamery. Pro práci byla použita klasifikace cévního řečiště pomocí neuronových sítí. Nejdříve došlo k naučení neuronu, jeho vstupem je libovolný snímek, ze kterého se učí rozpoznat a klasifikovat cévní řečiště.

Jako první, co bylo v této práci řešeno, je učení neuronu. Bylo zkoušeno několik různých kombinací učení z výřezu, na kterém jsou zastoupeny jak široké, tak i ty nejtenčí a zároveň nejméně viditelný šumy v pozadí. Druhé učení probíhalo z náhodně vybraných bodů v obraze. Na závěr se však ukázalo, že nejlepší výsledky jsou z učení pomocí výřezu. Další problematikou bylo nastavení počátečních parametrů, od kterých se odvíjí celý algoritmus učení. Posledním bylo nastavení aktivační funkce, která byla nakonec zvolena sinoida se strmostí 0,95.

Vybavování neboli klasifikace, byla provedena bez větších komplikací. Pomocí rovnice 4.2. bylo zkoušeno vybavování, prahování v jednom cyklu, ale výsledky se nejevily lepší, než vybavení a následné prahování. Vybavování je provedeno jen uvnitř masky, u které musel být nejdříve zmenšen vnitřní průměr, protože okraje masky do obrazu při vybavování přidávaly nežádoucí okraj.

Největší problém byla závěrečná úprava obrazu, protože klasifikací se celý obraz zvýraznil a tím vystoupil šum a nežádoucí artefakty. Velmi důležité proto bylo snímky správně prahovat, aby došlo k co nejlepším výsledkům. Bylo zkoušeno manuální prahování, kterému předcházela úprava klasifikovaného snímku, kdy byl snímku změněn kontrast. Manuální prahování sice zlepšilo klasifikaci tenčích cév, ale u snímku s nemocí došlo ke zvýraznění nežádoucích artefaktů. V práci bylo nakonec použito prahování pomocí Otsu metody, která se ukázala jako nejcitlivější na výpočet prahu.

Celý program byl otestován na databázi HRF, která obsahuje 15 zdravých snímků, 15 snímku postižených glaukomem a 15 s diabetickou retinopatií. Při testování byla počítána senzitivita, specificita a přesnost hodnocení, která představuje odchylku od skutečně měřené veličiny. Výsledky hodnocení byly porovnávány s metodou přizpůsobené filtrace a prahování [23]. Metoda popisovaná v této práci se u skupiny snímků zdravých pacientů jevila přibližně stejná, v některých případech i o něco slabší. U snímků nemocných pacientů se tento rozdíl zvětšil a metoda přizpůsobené filtrace se projevila jako silnější klasifikační nástroj.

Do budoucna by se dalo zabývat nalezením vhodnější metody prahování a závěrečné úpravy obrazu, aby bylo možné správně klasifikovat i malé cévky. Nebo použít místo přizpůsobené filtrace jinou metodu pro před úpravu, která lépe odstraní nežádoucí šum.

Použitá literatura

- [1] KOLÁŘ R.: *Diagnostika bio- a eko- systémů; Fundus kamery, konfokální mikroskopie přednáška* [pdf dokument]. ÚBMI VUT Brno. 2007 [cit. 24. listopadu 2012]. Dostupné z URL: http://www.ubmi.feec.vutbr.cz/~kolarr/mdbe/Kolar_MDBE_3.pdf
- [2] DOSTÁL, V.: *Předzpracování obrazů sítnice: diplomová práce*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2010. 60 s. Vedoucí diplomové práce doc. Ing. Radim Kolář, Ph.D.
- [3] SVOBODA, O.: *Hodnocení automatických metod segmentace cévního řečiště*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 56 s., 1 příloha. Vedoucí bakalářské práce Ing. Jan Odstrčilík.
- [4] *STructured Analysis of the Retina* [HTML dokument]. [cit. 25. listopadu 2012]. Dostupné z URL: <http://www.ces.clemson.edu/~ahoover/stare/>
- [5] DRIVE: *Digital Retinal Images for Vessel Extraction* [HTML dokument]. [cit. 25. listopadu 2012]. Dostupné z URL: <http://www.isi.uu.nl/Research/Databases/DRIVE/>
- [6] OPHTHALMIC DATA PROCESSING GROUP: *High-Resolution Fundus (HRF) Image Database* [HTML dokument]. [cit. 27. listopadu 2012]. Dostupné z URL: <http://ophtho.ubmi.feec.vutbr.cz/ophtho/page/hrf-database>
- [7] GIANINI A., GRISAN E., RUGGERI A.: *Enhanced Classification-Based Vessel Tracking Using Vessel Models and Hough Transform*. Proc. of the 3rd European Medical and Biological Engineering Conference EMBEC 2005. November 20-25, 2005, Prague, Czech Republic. vol. 11, no. 1, ISSN 1727-1983
- [8] PERFETTI R., RICCI E., CASALI D., COSTANTINI G.: *Cellular Neural Networks With Virtual Template Expansion for Retinal Vessel Segmentation*. IEEE Transactions on circuits and systems - II: Express briefs, vol. 54, no. 2, February 2007
- [9] RICCI E., PERFETTI R.: *Retinal Blood Vessel Segmentation Using Line Operators and Support Vector Classification*. IEEE Trans. October 2007. On Medical Imaging, vol. 26, No. 10. pp. 1357-1365.
- [10] CHANG Y., Hou-jin CH.: *Automated retinal blood vessels segmentation based on simplified PCNN and fast 2D-Otsu algorithm*. J. Cent. South Univ. Technol. (2009) 16: 0640–0646
- [11] MARÍN D., AQUINO A., GERÚNDEZ-ARIAS M. E., et al.: *A New Supervised Method for Blood Vessel Segmentation in Retinal Images by Using Gray-Level and Moment Invariants-based Features*. IEEE Trans. on Medical Imaging, vol. 30, no. 1, 2011.
- [12] ZANA F., KLEIN J. C. : *Segmentation of Vessel-Like Patterns Using Mathematical Morphology and Curvature Evaluation*. IEEE Transactions on image processing, vol. 10, no. 7, July 2001
- [13] CINSDIKICI G. M., AYDIN D.: *Detection of blood vessels in ophthalmoscope images using MF/ant (matched filter/ant colony) algorithm* Ege University Int'l Computer Institute, Izmir, Turkey
- [14] ODSTRČILÍK J., et al. *Improvement of Vessel Segmentation by Matched Filtering in Colour Retinal Images*. IFMBE Proceedings, vol. 25, pp. 327-330, 2009.

- [15] OTSU, N A *Threshold Selection Method from Gray-Level Histograms*. IEEE Trans. on Systems, Man, and Cybernetics 9(1):62-66, 1979
- [16] DUDA R. O., HART P. E., STORK D.G.: *Pattern classification* (2ed., Wiley, 2000), (ISBN 0471056693)(738s)
- [17] KOZUMPLÍK J., PROVAZNÍK I.: *Umělá inteligence v medicíně* [pdf dokument]. ÚBMI VUT Brno, 2007.
- [18] *Zdroj obrázku fundus kamery* [HTML dokument]. [cit. 11. prosince 2012]. Dostupné z URL: <<http://www.kubena.cz/text/o-nas/pristrojove-vybaveni.php>>
- [19] *Zdroj schématu perceptronu* [HTML dokument]. [cit. 11. prosince 2012]. Dostupné z URL: < <http://cz.wikipedia.org/wiki/Perceptron> >
- [20] ROZSÍVAL, P. *Oční lékařství*. 1. vyd. Praha: Galén, Karolinum, 2006. 373 s. ISBN 8072624040
- [21] HO A. C., BROWN C. G., McNAMARA A. J., RECCHIA M. F., REGILLO D. C., VANDER F. J.: *Color atlas & synopsis of clinical ophthalmology, Wills eye hospital*, 2003. pp. 2-129, ISBN: 0-07-137596-1
- [22] PROVAZNÍK I: *Úvod do biomedicínské informatiky; Pravděpodobnost v rozhodování-přednáška* [pdf dokument]. ÚBMI VUT Brno. 2011.
- [23] ODSTRČILÍK J., et al., *Retinal Vessel Segmentation by Improved Matched Filtering: Evaluation on a New High-Resolution Fundus Image Database.*, IET Image Processing, vol. 4, p.12, 2013. ISSN 1751-9659

8. Použité zkratky

HRF	High-Resolution Fundus Image Database - databáze snímku z fundus kamery
FOV	Field of View – zorné pole
RGB	Red-Green-Blue – kanály v obraze
TPR	True positive rate
FPR	False positive rate
TP	True positive
FP	False positive
TN	True negative
FN	False negative
ACC	Accuracy – přesnost měření